This Page Is Inserted by IFW Operations and is not a part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images may include (but are not limited to):

- BLACK BORDERS
- TEXT CUT OFF AT TOP, BOTTOM OR SIDES
- FADED TEXT
- ILLEGIBLE TEXT
- SKEWED/SLANTED IMAGES
- COLORED PHOTOS
- BLACK OR VERY BLACK AND WHITE DARK PHOTOS
- GRAY SCALE DOCUMENTS

IMAGES ARE BEST AVAILABLE COPY.

As rescanning documents will not correct images, please do not report the images to the Image Problems Mailbox.

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平11-39306

(43) 公開日 平成11年(1999) 2月12日

(51) Int.Cl.⁶

G06F 17/27

17/28

識別記号

FI G06F 15/20

)

550F

592A

15/38

D

審査請求 未請求 請求項の数22 OL (全 26 頁)

(21)出願番号

特顧平9-191571

(22)出顧日

平成9年(1997)7月16日

(71)出願人 000002185

ソニー株式会社

東京都品川区北品川6丁目7番35号

(72)発明者 アレキサンダー フランツ

東京都品川区北品川6丁目7番35号 ソニ

一株式会社内

(72)発明者 堀口 恵子

東京都品川区北品川6丁目7番35号 ソニ

一株式会社内

(74)代理人 弁理士 山口 邦夫 (外1名)


(54) 【発明の名称】 多言語情報の処理システムおよび処理方法

(57)【要約】

【課題】入力文書の言語が母国語でない場合や入力文書 が大量である場合でも、ユーザによって入力文書中の情報を容易に理解可能にする。

【解決手段】入力文書の要約部、さらには入力文書やその要約結果を他の自然言語に翻訳する翻訳部を備える。ローカル又はリモートの情報源から入力文書(ファクシミリ文書、電子メイル文書、指定ファイル等)を受領し(ST1)、この入力文書に対して言語の判定や分野を、if-then推論規則や統計情報を使用して判定する(ST2、ST3)。入力文書に対して要約が必要であるときは、要約部によって要約を作成する(ST4、ST5)。この要約は、例えばテンプレートのスロットを埋めることで作成する。また、入力文書や要約結果に対して他の言語への翻訳が必要であるときは、翻訳部によって翻訳を作成する(ST6、ST7)。そして、言語判定結果、分野判定結果、要約結果、翻訳結果等を、ローカルまたはリモートのユーザに送る(ST8)。

多言語情報処理システムの動作概要



【特許請求の範囲】

【請求項1】 自然言語で書かれた入力文書を受領する 文書受領手段と、

上記入力文書の言語を判定する言語判定手段と、

上記言語判定手段の言語判定結果を利用し、上記入力文 也の要約を作成する要約作成手段とを備えることを特徴 とする多言語情報処理システム。

【請求項2】 上記要約作成手段は、要約テンプレート を用いて上記入力文書を要約することを特徴とする請求 項1に記載の多言語情報処理システム。

【請求項3】 ユーザからの要約の仕様を受領する要約 受領手段をさらに備え、

上記要約作成手段は、上記要約の仕様に含まれる要約方法の情報に基づき、上記入力文書を要約テンプレートを 用いて要約することを特徴とする請求項2に記載の多言 語情報処理システム。

【請求項4】 上記要約テンプレートのデータベースを さらに備え、

上記要約作成手段は、上記要約の仕様に要約テンプレー 【請求項15】 自然電 トの指定情報が含まれるとき、上記データベースより指 20 る文書受領ステップと、 定された要約テンプレートを選択して用いることを特徴 上記入力文書の言語を半 とする請求項3に記載の多言語情報処理システム。 上記言語判定ステップの

【請求項5】 上記要約テンプレートのデータベースを さらに備え、

上記要約作成手段は、上記要約の仕様に要約テンプレートの指定情報が含まれていないとき、上記データベースより上記入力文書に最適な要約テンプレートを選択して用いることを特徴とする請求項3に記載の多言語情報処理システム。

【請求項6】 上記要約作成手段は、規則および統計情報を用いて上記入力文書を要約することを特徴とする請求項1に記載の多言語情報処理システム。

【請求項7】 ユーザからの要約の仕様を受領する要約 仕様受領手段をさらに備え、

上記要約作成手段は、上記要約の仕様に含まれる要約方法の情報に基づき、上記入力文書を規則および統計情報を用いて要約することを特徴とする請求項6に記載の多言語情報処理システム。

【請求項8】 上記要約作成手段は、上記要約の仕様に 含まれる要約率または要約結果の長さの情報に適合する ように上記入力文書を要約することを特徴とする請求項 7に記載の多言語情報処理システム。

【請求項9】 ユーザからの入力の仕様を受領する入力 仕様受領手段をさらに備え、

上記文書受領手段は、上記入力の仕様に含まれる入手場所の指定情報で指定される入手場所からの上記入力文書を受領することを特徴とする請求項1に記載の多言語情報処理システム。

【請求項10】 多様な言語の文字認識手段をさらに備え、

上記文書受領手段は、上記入手場所がファクシミリであって、上記入力文書をイメージデータで受領するとき、 上記文字認識手段によって上記イメージデータをテキス

トデータに変換することを特徴とする請求項9に記載の 多言語情報処理システム。

2

【請求項11】 上記入力文書の分野を判定する分野判定手段をさらに備えることを特徴とする請求項1に記載の多言語情報処理システム。

【請求項12】 上記入力文書またはその要約を、他の 10 自然言語に翻訳する翻訳手段をさらに備えることを特徴 とする請求項1に記載の多言語情報処理システム。

【請求項13】 上記要約作成手段で作成された上記入力文書の要約を送信する情報送信手段をさらに備えることを特徴とする請求項1に記載の多言語情報処理システム。

【請求項14】 上記翻訳手段で翻訳された結果を送信する情報送信手段をさらに備えることを特徴とする請求項12に記載の多言語情報処理システム。

【請求項15】 自然言語で書かれた入力文書を受領す の る文書受領ステップと、

上記入力文書の言語を判定する言語判定ステップと、 上記言語判定ステップの言語判定結果を利用し、上記入 力文書の要約を作成する要約作成ステップとを備えることを特徴とする多言語情報処理方法。

【請求項16】 上記要約作成ステップでは、要約テンプレートを用いて上記入力文書を要約することを特徴とする請求項15に記載の多言語情報処理方法。

【請求項17】 ユーザからの要約の仕様を受領する要約受領ステップをさらに備え、

30 上記要約作成ステップでは、上記要約の仕様に含まれる 要約方法の情報に基づき、上記入力文書を要約テンプレ ートを用いて要約することを特徴とする請求項16に記 載の多言語情報処理方法。

【請求項18】 上記要約作成ステップでは、上記要約の仕様に要約テンプレートの指定情報が含まれるとき、要約テンプレートのデータベースより指定された要約テンプレートを選択して用いることを特徴とする請求項17に記載の多言語情報処理方法。

【請求項20】 上記要約作成ステップでは、規則および統計情報を用いて上記入力文書を要約することを特徴とする請求項15に記載の多言語情報処理方法。

【請求項21】 ユーザからの要約の仕様を受領する要約仕様受領ステップをさらに備え、

上記要約作成ステップでは、上記要約の仕様に含まれる 50 要約方法の情報に基づき、上記入力文書を規則および統

計情報を用いて要約することを特徴とする請求項20に 記載の多言語情報処理方法。

【請求項22】 上記要約作成ステップでは、上記要約の仕様に含まれる要約率または要約結果の長さの情報に適合するように上記入力文書を要約することを特徴とする請求項21に記載の多言語情報処理方法。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】この発明は、多くの自然言語で構成された文書に記載された大量の情報を取り扱う際に適用して好適な多言語情報の処理システムおよび処理方法に関する。詳しくは、入力文書を要約する機能、さらには入力文書やその要約を他の自然言語に翻訳する機能を持たせることによって、文書中の情報をユーザが容易に理解し得るようにした多言語情報処理システム等に係るものである。

[0002]

【従来の技術】情報を含有する文書を受け取り、データベースに保存し、様々な基準に基づいて抽出してユーザに表示するデータベースシステムまた手法はすでに存在する(例えば、Salton、Gerard: and McGill、Michael J. 1983. "Introduction to ModernInformation Retrieval." New York: McGraw-Hill.参照)。

【0003】このようなデータベースシステムにおいて、関係する文書が大量にあったり非常に長いものであった場合、ユーザはすべてを読んで内容を理解することができない場合があった。さらにデータベースに保存されている文書がユーザの理解し得ない言語で書かれている場合には、その文書の情報を理解することも不可能であった。文書を受け取り、他の自然言語に翻訳し、結果をユーザに表示する自動翻訳システムや手法もすでに存在する(例えば、US Patent 5528491 "Apparatus and method for automated natural language translation"参照)。

【0004】しかし、もとの文書が大量にあったり非常に長いものであった場合、ユーザはすべての翻訳結果を読み、もとの文哲に書かれていた情報をすべて理解することは困難であった。さらに、自動翻訳システムによる出力の質はいまだに高くはなく、人間が書いた文章に比べてほとんど常に劣っている。そのため、自動翻訳システムからの出力を人間が書いた文章のようにすばやく読んで理解することは非常に難しい。結果として、自動翻訳された文書を読むのにはさらに長い時間がかかり、情報管理の問題をさらに悪化させている。

【0005】自動翻訳システムによってある言語から他の言語に文書を翻訳し、結果を自動的に音声合成してユーザに提示する手法やシステムもすでに存在する。そのように翻訳・合成された結果を理解しやすくする技術も開発されている。例えば、USpatent 5546500 "Arrang ement for increasing the comprehension of speech w

hen translating speech from a first language to a second language"には、入力音声の韻律情報を出力音声に転写させる技術が書かれている。

しかし、ある言語から他の言語への自動翻訳結果には、語や句の誤選択、誤削除、文法上の誤りなど、様々な誤りが含まれている。そのような誤りを含んだまま音声出力が合成された場合、ユーザには不自然な音声となり、長い間注意を集中して内容を聴き取り理解することはきわめて難しい作業となる。さらに、すぐ前の部分を簡単に読み返すことの出来る文書と異なり、音声で出力された場合には、前に読まれた単語や句、文などを聞き返すことが容易には出来ない。さらに、いわゆる「斜め読み」をして要点をつかむことの出来る文書と異なり、音声で出力された場合には、とばして速く要点をつかむことができない。

【0006】SGML (Standard Generalized Markup Language) やHTML (HypertextMarkup Language) のようなタグのついた文書を翻訳する自動翻訳システムについては、例えば、US Patent 5548508 "Machine Translation apparatus for translating document with tag"に示されている。

【0007】この装置は、文書中のSGMLタグを判別し、文書に追加すべき情報を明記した定義ファイルを参照しながら、文書に必要な情報を追加する。この装置は情報を追加するのみであり、SGMLタグから文書の特徴やメタ情報を判別したりすることはなく、そのような文書の特徴やメタ情報を独立した記憶バッファに保存するようなこともせず、文書の特徴やメタ情報を使って、複数の翻訳部の中から適切な処理部を選択するのに使用することもせず、文書の特徴やメタ情報を使って、複数の翻訳用データベースの中から適切なものを選択するのに使用することもしない。

【0008】入力文書の全体または一部を翻訳する機械翻訳システムは、例えば、US Patent 4814988 "Machine Translation system translating all or a selected portion of an input sentence"に示されている。このシステムは、入力文母の全体を必ずしも翻訳しない。そのかわり、ユーザに翻訳してほしい部分を指示させ、その部分のみ翻訳することが出来る。また、ユーザに翻訳して欲しくない部分を指示させ、その部分を除いて翻訳することもできる。このようなシステムにおいて、ユーザはもとの文書を理解し、どこが翻訳されるべきか(またはされないべきか)を判定することができなければならない。さらにユーザは翻訳する部分を確定するためにもとの文章をもとの言語で読まなければならない。【0009】文售を分類するシステムと手法は、例え

ば、US Patent 5182708 "Method and Apparatus for classifying text"に示されている。この手法は、文書を様々なカテゴリーに分類するために、文書中の異なる

単語数や単語の長さに基づく統計手法を用いる。この手 法はある力テゴリーに特徴的な特定の単語やパターンを 考慮に入れてはおらず、SGMLやHTMLのタグで表 されたような注釈を考慮に入れてもいない。

【0010】テーマにより文書を要約する手法とシステ ムは、例えば、US Patent 5384703" Method and appara tus for summarizing documents according to theme" に示されている。この手法では、再帰的に文書中の一部 を選択していくことにより要約を作成する。選択するの は、まず文書中にもっとも頻繁に表れる表現を探し、そ の表現を含む部分からである。この手法では、頻繁には 表れないが文書中の重要な部分を示唆するパターンなど を利用することはできない。さらに分野に特有のパター ンや規則も利用しない。

【0011】単語コードを使用した言語/分野判定手法 は、例えば、US Patent 5546507" Language identifica tion process using coded language words" に示され ている。この手法では、特定の言語や分野を示唆する単 語の表れる頻度を加算して行き、加算結果のもっとも多 い言語または分野を選択する。この手法は文書自体に含 まれているSGMLやHTMLタグのようなメタ情報を 利用したり、言語や分野を特定するためのif-then推定 規則を利用したりはしない。

[0012]

【発明が解決しようとする課題】我々は文章の形での膨 大な量の情報に毎日接している。電子メイル、ワールド ワイドウェブのページ上の文書、ファクシミリからの文 書、データベースの文書、その他様々なところからの情 報が文書の形でやってくる。さらにそれら文書は異なる 自然言語で書かれている。国際ビジネス、ワールドワイ ドウェブのような全地球的な情報ネットワーク、ファク シミリや電子メイルのような国際通信などの発達に伴 い、母国語以外で書かれた文書に接する機会も増えてい る。このような状況で文書中の情報量が多すぎてすべて を理解するのが不可能であったり、外国語でむかれてい るために内容を理解するのが不可能であるといった問題 が発生する。

【0013】そこで、この発明では、文書中の情報をユ ーザが容易に理解し得るようにした多言語情報処理シス テム等を提供することを目的とする。

[0014]

【課題を解決するための手段】この発明に係る多言語情 報処理システムは、自然言語で書かれた入力文書を受領 する文書受領手段と、この入力文書の言語を判定する言 語判定手段と、この言語判定手段の言語判定結果を利用 し、入力文書の要約を作成する要約作成手段とを備える ものである。

【0015】また、この発明に係る多言語情報処理方法 は、自然言語で書かれた入力文書を受領する文書受領ス テップと、入力文書の言語を判定する言語判定ステップ 50 ォン104より入力される音声を認識するための音声認

と、言語判定ステップの言語判定結果を利用し、入力文 書の要約を作成する要約作成ステップとを備えるもので ある。

6

【0016】この発明においては、自然言語で書かれた 入力文書が受領される。この場合、ユーザからの入力の 仕様に含まれる入手場所の指定情報で指定される入手場 所、例えばファクシミリ、電子メイル、ファイルまたは データベース等からの入力文書が受領される。そして、 この入力文書の言語の判定が行われる。この言語の判定 では、例えばif-then推論規則が適用されて候補言語が ランキングされる。

【0017】そして、言語の判定結果を利用し、入力文 書の要約が作成される。例えば、要約は、要約テンプレ ートを用いて作成され、あるいは規則および統計情報を 用いて作成される。要約テンプレートを用いて要約を作 成する場合、ユーザからの要約の仕様で指定された要約 テンプレートがデータベースより読み出されて使用さ れ、あるいはデータベースより入力文書に最適な要約テ ンプレートが読み出されて使用される。規則および統計 情報を用いて要約を作成する場合、ユーザからの要約の 仕様に含まれる要約率や要約結果の長さの情報に適合す るように入力文書の要約が行われる。

【0018】入力文書またはその要約を、他の自然言語 に翻訳する翻訳手段を備えていてもよい。これにより、 例えば入力文書やその要約結果をユーザの理解可能な所 望の言語に翻訳することが可能となる。そして、要約結 果や翻訳結果は、例えばユーザの指示によってローカル またはリモートの設備に送信される。

[0019]

【発明の実施の形態】以下、図面を参照しながら、この 発明の実施の形態を説明する。図1は、実施の形態とし ての、多言語情報処理システム10の構成を示してい る。この処理システム10は、出入力インタフェース部 100と、CPU (central processingunit) 200 と、記憶装置300とを有して構成されている。

【0020】出入力インタフェース部100は、電話回 線に接続するための電話回線インタフェース101と、 LAN (Local Area Network) 等のネットワークに接続 するためのネットワークインタフェース102と、各種 40 の仕様等をユーザがキー入力するためのキーボード10 3と、その各種の仕様等をユーザが音声で入力するため のマイクロフォン104と、各種の仕様等をモニタの画 面上で入力するためのマウスやタッチスクリーン等10 5と、処理システム10の状態や処理結果等を表示する 液晶素子等で構成されるモニタ106とを有している。 【0021】CPU200は、実質的に以下の機能部を 有している。すなわち、CPU200は、出入力インタ フェース部100との間で様々なデータのやり取りを行

うためのユーザインタフェース部201と、マイクロフ

譤部202と、この音声認識部202の認識結果やユー ザのキーボード103からの入力言語を理解してシステ ム言語コマンドに翻訳するための自然言語理解部203 と、後述するように要約結果や翻訳結果を電話に送信す るために音声信号を合成する音声合成部204とを有し ている。そして、ユーザインタフェース部201には、 出入力コントロール部205と、エラーメッセージを生 成するエラーメッセージ生成部206が備えられてい る。

【0022】また、CPU200は、後述する言語判 定、分野判定、要約および翻訳の対象となる入力文書を 受領するための入力受領部211と、後述する要約結果 や翻訳結果をユーザが指定する場所に送信するための出 力部212と、入力文書の言語を判定する言語判定部2 13と、入力文書の分野を判定する分野判定部214 と、入力文書の要約を作成する要約部215と、入力文 書やその要約結果を他の自然言語に翻訳する翻訳部21 6と、これら入力受領部211、出力部212、言語判 定部213、分野判定部214、要約部215および翻 訳部216の動作を制御する中央制御部217とを有し ている。

【0023】図2のフローチャートを使用して、処理シ ステム10の動作概要を説明する。まず、ステップST 1で、入力受領部211によってローカルまたはリモー トの情報源からの入力文書を受領し、この入力文書を記 憶装置300の記憶バッファ301に記憶する。次に、 ステップST2で、言語判定部212によって、記憶バ ッファ301に記憶した入力文書の言語を判定し、その 判定結果を記憶装置300の記憶バッファ302に記憶 する。

【0024】次に、ステップST3で、分野判定部21 4によって、記憶バッファ301に記憶した入力文書の 分野を判定し、その判定結果を記憶装置300の記憶バ ッファ303に記憶する。次に、ステップST4で、要 約が必要か否かを判定し、必要であるときは、ステップ ST5で、要約部215によって、記憶バッファ302 に記憶した言語判定結果を利用し、記憶バッファ301 に記憶した入力文書の要約を作成し、その要約結果を記 憶装置300の記憶バッファ304に記憶する。

【0025】次に、ステップST6で、入力文書または 記憶バッファ305に記憶した要約結果の翻訳が必要か 否かを判定し、必要であるときは、ステップST7で、 翻訳部216によって、入力文書または要約結果を他の 自然言語に翻訳し、その翻訳結果を記憶装置300の記 憶パッファ305に記憶する。次に、ステップST8 で、出力部212によって、記憶バッファ302~30 5 等に記憶した言語判定結果、分野判定結果、要約結 果、翻訳結果等を、ローカルまたはリモートのユーザに 送る。

【0026】なお、記憶装置300には、上述したよう *50* 11dによって、ローカルまたはリモートにあるSGM

にマイクロホン104を使用して音声入力され、あるい

はキーボード103よりキー入力されるユーザからの仕 様を記憶する記憶バッファ306も設けられている。

【0027】図3は、入力受領部211の構成を示して いる。この入力受領部211は、全体の動作を制御する 入力受領制御部211aと、記憶装置300の記憶バッ ファ306より、入力仕様を抽出して入力受領制御部2 11aに供給するユーザ仕様抽出部211bと、入力文 **書として電子メイル文書を受領するための電子メイル受** 10 領部211cと、入力文書としてSGML/HTML文 書を受領するためのSGML/HTML受領部211d と、ローカルまたはリモートのファイルやデータベース から指定ファイルを受領するファイル/データベース受 領部211eとを有している。

【0028】また、入力受領部211は、入力文書とし てファクシミリ文書を受領するためのファクシミリ受領 部211fを有している。このファクシミリ受領部21 1 f は、全体の動作を制御するファクシミリ入力受領制 御部211gと、記憶装置300の記憶バッファ306 20 より、言語仕様を抽出して入力受領制御部211gに供 給するユーザ仕様抽出部211hと、イメージデータを テキストデータに変換するための言語 1 ~ 言語 n のため のn個の文字認識部211k₁~211k_nとを有してい

【0029】図4のフローチャートを使用して、入力受 領部211の動作を説明する。ステップST11で、入 力文書の入手場所を指定するユーザからの入力仕様を取 得する。この場合、ユーザ仕様抽出部211bは、記憶 装置300の記憶バッファ306より入力仕様を抽出 30 し、この入力仕様を入力受領制御部211aに供給す る。そして、ステップST12で、入力仕様がファクシ ミリ文書の受領を指定しているか否かを判定する。ファ クシミリ文書の受領を指定しているときは、ステップS T13で、後述するファクシミリ文書の受領動作をす

【0030】ステップST12でファクシミリ文書の受 領を指定していないときは、ステップST14で、電子 メイル文書の受領を指定しているか否かを判定する。電 子メイル文書の受領を指定しているときは、ステップS T15で、電子メイル受領部211cによって、出入力 コントロール部205を介して指定の電子メイル文書 (テキストデータ) を受領する。そして、ステップST 16で、受領した電子メイル文書を入力文書として記憶 装置300の記憶バッファ301に記憶する。

【0031】ステップST14で電子メイル文書の受領 を指定していないときは、ステップST17で、SGM L/HTML文書の受領を指定しているか否かを判定す る。SGML/HTML文書の受領を指定しているとき は、ステップST18で、SGML/HTML受領部2

LやHTMLのファイルより、出入力コントロール部205を介して、指定のSGML文書やHTML文書(テキストデータ)を受領する。そして、ステップST19で、受領したSGML文書やHTML文書を入力文書として記憶バッファ301に記憶する。

【0032】ステップST17でSGML/HTML文 むの受領を指定していないときは、ステップST20で ファイルやデータベースからの入力を指定するものであるか否かを判定する。ファイルやデータベースからの入力を指定するものであるときは、ステップST21で、 ファイル/データベース受領部211eによって、ローカルまたはリモートにあるファイルやデータベースより、出入力コントロール部205を介して、指定のファイル(テキストデータ)を受領する。そして、ステップST22で、受領したファイルを入力文書として記憶バッファ301に記憶する。

【0033】ステップST20で、ファイルやデータベースからの入力を指定するものでないときは、ステップST23で、入力受領制御部211aは中央制御部217にエラー情報を送る。これにより、中央制御部217よりユーザインタフェース部201にエラー情報が供給され、エラーメッセージ部206でエラーメッセージが生成され、例えば出入力インタフェース部100のモニタ106にエラーメッセージが表示される。

【0034】図5のフローチャートを使用して、ファクシミリ文書の受領動作を説明する。ステップST31で、ファクシミリ受領部211fによって、出入力コントロール部205を介して、ファクシミリ文書(イメージデータ)を受領する。そして、ステップST32で、ユーザ仕様抽出部211hによって、ファクシミリ文書の自然言語を示すユーザからの言語仕様を取得する。この場合、ユーザ仕様抽出部211hは、記憶装置300の記憶バッファ306より言語仕様を抽出し、この言語仕様をファクシミリ入力受領制御部211gに供給する

【0036】一方、言語仕様で示される自然言語が言語 1~言語nのいずれでもないときは、ステップST36 で、ファクシミリ入力受領制御部211gは入力受領制御部211aにエラー情報を送る。これにより、中央制御部217sよりユーザインタフェース部201にエラー

情報が供給され、エラーメッセージ部206でエラーメッセージが生成され、例えば出入力インタフェース部100のモニタ106にエラーメッセージが表示される。【0037】図6は、言語判定部213の構成を示している。この言語判定部213は、全体の動作を制御する言語判定制御部213aと、記憶装置300の記憶バッファ306より、入力文書の言語を示す言語仕様を抽出して言語判定制御部213aに供給するユーザ仕様抽出部213bと、記憶装置300の記憶バッファ301に記憶されている入力文書を、SGMLやHTMLのタグ、その他のデータ、単語、句、文、その他のユニットに分割する文章分割部213cとを有している。

10

【0038】また、言語判定部213は、入力文書に含まれる、その入力文書の言語を示す注釈やタグを解析して入力文書の言語を判定するタグ等解析部213dと、入力文書の特定の単語、句やパターンが存在するか否かによって文書がどの言語で書かれている確率が高いかを、規則データベース213eからのif-then推論規則データを適用して判定し、候補言語をランキングする規20 則による言語判定部213fと、1また複数バイトのパターンの起こる頻度(n-grams)とそれぞれの言語との相関関係を示す統計データベース213gからの統計情報を利用し、入力文書中のパターンの起こる頻度と比較し、その結果を用いて候補言語のランキングを調整し、最上位ランキングの言語を判定結果とする統計情報による言語判定部213hとを有している。

【0039】図7のフローチャートを使用して、言語判定部213の動作を説明する。ステップST41で、文章分割部213cによって、記憶バッファ301に記憶のされている入力文書をSGMLやHTMLのタグ、その他のデータ、単語、句、文、その他のユニットに分割し、その分割済入力文書を記憶装置300の記憶バッファ307に記憶する。

【0040】次に、ステップST42で、記憶バッファ307に記憶している分割済み入力文書に基づき、入力文書に、その言語を示す注釈やタグを含むか否かを判定する。言語を示す注釈やタグを含むときは、ステップST43で、タグ等解析部213dによって、注釈やタグから入力文書の言語情報を取得し、ステップST44で、その取得した言語情報を言語判定結果として記憶装置300の記憶バッファ302に記憶する。

【0041】ステップST42で言語を示す注釈やタグを含まないときは、ステップST45で、ユーザが言語仕様を入力したか否かを判定する。言語仕様を入力しているときは、ステップST46で、ユーザ仕様抽出部213bによって、記憶装置300の記憶バッファ306より言語仕様を抽出することで、ユーザからの言語情報を取得し、ステップST44で、その取得した言語情報を言語判定結果として記憶装置300の記憶バッファ35002に記憶する。

【0042】次に、ステップST45でユーザが言語仕様を入力していないときは、ステップST47で、規則による言語判定部213fによって、記憶バッファ307に記憶している分割済み入力文書を利用し、if-then推論規則により、入力文書に特定の単語、句やパターンが存在するかどうかで、その入力文書がどの言語で書かれている確率が高いかを判定し、候補言語をランキングする。この候補言語のリストは、統計情報による言語判定部213hに供給される。ここで、if-then推論規則とは、「もしAがBであるならDという処理を実行する」といった、場合分けをし、場合毎に実行すべき処理を規定する規則である。

【0043】次に、ステップST48で、言語判定部213hによって、記憶バッファ307に記憶している分割済み入力文書を利用し、入力文書中のパターンの起こる頻度と統計情報とを比較し、その結果を用いて候補言語のランキングを調整し、最上位の候補言語を最も確からしい言語として選択する。そして、ステップST44で、その選択された言語の情報を言語判定結果として記憶を置300の記憶バッファ302に記憶する。

【0044】図8は、分野判定部214の構成を示している。この分野判定部214は、全体の動作を制御する言語判定制御部214aと、記憶装置300の記憶バッファ306より、入力文書の分野を示す分野仕様を抽出して分野判定制御部214aに供給するユーザ仕様抽出部214bと、記憶装置300の記憶バッファ301に記憶されている入力文書を、SGMLやHTMLのタグ、その他のデータ、単語、句、文、その他のユニットに分割する文章分割部214cとを有している。

【0045】また、分野判定部214は、入力文書に含まれる、その入力文書の言語を示す注釈やタグを解析して入力文書の分野を判定するタグ等解析部214dと、入力文書の特定の単語、句やパターンが存在するかかをによって文書がどの分野に属している確率が高いかを、規則データベース214eからのif-then推論規則データを適用して判定し、候補分野をランキングする規則による分野判定部214fと、1また複数バイトのパターンの起こる頻度(n-grams)とそれぞれの分野との相関関係を示す統計データベース214gからの統計情報を利用し、入力文書中のパターンの起こる頻度と比較し、その結果を用いて候補分野のランキングを調整し、最上位ランキングの言語を判定結果とする統計情報による分野判定部214hとを有している。

【0046】図9のフローチャートを使用して、分野判定部214の動作を説明する。ステップST51で、文章分割部214cによって、記憶バッファ301に記憶されている入力文書をSGMLやHTMLのタグ、その他のデータ、単語、句、文、その他のユニットに分割し、その分割済入力文書を記憶装置300の記憶バッフ

ァ307に記憶する。

【0047】次に、ステップST52で、記憶バッファ307に記憶した分割済み入力文書に基づき、入力文書に、その分野を示す注釈やタグを含むか否かを判定する。分野を示す注釈やタグを含むときは、ステップST53で、タグ等解析部214dによって、注釈やタグから入力文書の分野情報を取得し、ステップST54で、その取得した分野情報を分野判定結果として記憶装置300の記憶バッファ303に記憶する。

12

【0048】ステップST52で分野を示す注釈やタグを含まないときは、ステップST55で、ユーザが分野仕様を入力したか否かを判定する。分野仕様を入力しているときは、ステップST56で、ユーザ仕様抽出部214bによって、記憶装置300の記憶バッファ306より分野仕様を抽出することで、ユーザからの分野情報を取得し、ステップST54で、その取得した分野情報を言語判定結果として記憶装置300の記憶バッファ303に記憶する。

【0049】次に、ステップST55でユーザが分野仕り様を入力していないときは、ステップST57で、規則による分野判定部214fによって、記憶バッファ307に記憶している分割済み入力文書を利用し、if-then推論規則により、入力文書に特定の単語、句やパターンが存在するかどうかで、その入力文書がどの分野に属する確率が高いかを判定し、候補分野をランキングする。この候補分野のリストは、統計情報による分野判定部214hに供給される。

【0050】次に、ステップST58で、分野判定部2 14hによって、記憶バッファ307に記憶している分 30 割済み入力文書を利用し、入力文書中のパターンの起こ る頻度と統計情報とを比較し、その結果を用いて候補分 野のランキングを調整し、最上位の候補分野を最も確か らしい分野として選択する。そして、ステップST54 で、その選択された候補分野の情報を分野判定結果とし て記憶装置300の記憶バッファ303に記憶する。

【0051】図10は、要約部215の構成を示している。この要約部215は、全体の動作を制御する要約制御部215aと、記憶装置300の記憶バッファ306より、要約仕様を抽出して要約制御部215aに供給するユーザ仕様抽出部215bと、記憶装置300の記憶バッファ301に記憶されている入力文書に対してテンプレートを使って要約を作成するテンプレートによる要約部219と、同様に入力文書に対して規則および統計情報を使って要約を作成する規則と統計情報による要約部218とを有している。

【0052】図11のフローチャートを使用して、要約部215の動作を説明する。ステップST61で、ユーザからの要約仕様を取得する。この場合、ユーザ仕様抽出部215bは、記憶装置300の記憶バッファ306より要約仕様を抽出し、この要約仕様を要約制御部21

5 a に供給する。そして、ステップST62で、要約仕様がテンプレートによる要約を指定しているか否かを判定する。テンプレートによる要約を指定しているときは、ステップST63で、要約部219によって、記憶バッファ301に記憶されている入力文書に対して、テンプレートを使って要約を作成し、その要約結果を記憶装置300の記憶バッファ304に記憶する。

【0053】ステップST62でテンプレートによる要約を指定していないときは、ステップST64で、要約仕様が規則および統計情報による要約を指定しているか否かを判定する。規則および統計情報による要約を指定しているときは、ステップST65で、要約部218によって、規則および統計情報を使って要約を作成し、その要約結果を記憶バッファ304に記憶する。

【0054】ステップST64で規則および統計情報による要約を指定していないときは、適当な要約方法の指定がなかったものとして、ステップST66で、要約制御部215aは中央制御部217にエラー情報を送る。これにより、中央制御部217よりユーザインタフェース部201にエラー情報が供給され、エラーメッセージ部206でエラーメッセージが生成され、例えば出入力インタフェース部100のモニタ106にエラーメッセージが表示される。

【0055】図12は、テンプレートによる要約部219の構成を示している。要約部219は、全体の動作を制御する要約制御部219aと、記憶装置300の記憶バッファ306よりユーザからのテンプレートの指定情報を抽出し、テンプレートデータベース219bよりその指定情報で指定されたテンプレートを選択するテンプレート選択部219cと、ユーザからのテンプレートの指定情報がないとき、テンプレートデータベース219bより最適なテンプレートを選択するテンプレート自動選択部219dとを有している。

【0056】また、要約部219は、記憶装置300の記憶バッファ302に記憶されている言語判定結果を利用して、記憶バッファ301に記憶されている入力文書を単語、句、文等に分割する文章分割部219eと、テンプレート選択部219cまたはテンプレート自動選択部219dで選択されたテンプレートを使った要約の作成を実行するテンプレート実行部219fとを有している。

【0057】図13のフローチャートを使用して、テンプレートによる要約部219の動作を説明する。ステップST71で、ユーザからのテンプレートの指定があるか否かを判定する。ユーザからのテンプレートの指定があるときは、ステップST72で、テンプレート選択部219cによって、記憶バッファ306よりユーザからのテンプレートの指定情報を抽出し、テンプレートデータベース219bよりその指定情報で指定されたテンプレートを選択し、そのテンプレートを要約作成に使用す

るテンプレートとして記憶装置300の記憶バッファ308に記憶する。一方、ユーザからのテンプレートの指定がないときは、ステップST73で、テンプレート自動選択部219dによって、テンプレートデータベース219bより最適なテンプレートを選択し、そのテンプレートを要約作成に使用するテンプレートとして記憶バッファ308に記憶する。

【0058】次に、ステップST74で、記憶装置300の記憶バッファ301に記憶されている入力文書の言語を判定する。この場合、記憶装置300の記憶バッファ302に記憶されている上述した言語判定部213による言語判定結果を利用できる。そして、ステップST75で、この言語判定結果に基づき、文章分割部219eによって、入力文書を単語、句、文等に分割し、その分割済入力文書を記憶装置300の記憶バッファ309に記憶する。

【0059】次に、ステップST76で、テンプレート 実行部219fによって、テンプレート中の各スロット に含まれている情報抽出のためのif-then推論規則を実 20 行する。そして、ステップST77で、同様にテンプレ ート実行部219fによって、テンプレート中の各スロ ットに含まれている情報表示のためのif-then推論規則 を実行し、ステップST78で、その実行結果を要約結 果として、記憶装置300の記憶バッファ304に記憶 する。

【0060】図14は、規則と統計情報による要約部2 18の構成を示している。要約部218は、全体の動作 を制御する要約制御部218aと、記憶装置300の記 憶バッファ306よりユーザからの要約率または要約結 果の長さの指定情報を抽出し、その要約率の指定情報を 要約制御部218aに供給するユーザ仕様抽出部218 bと、記憶装置300の記憶バッファ302に記憶され ている言語判定結果を利用して、記憶バッファ301に 記憶されている入力文書を単語、句、文等に分割する文 章分割部218cとを有している。

【0061】また、要約部218は、文章分割部218 cによって分割された分割済入力文書より、単語や句の現れる頻度や互いの近さ等の特徴を取得する入力文書特徴取得部218dと、特定の単語や句、その他のパター 20の存在、その順番、互いの近さ等が要約における有効性にどんな影響があるかについての規則データベース214eからのif-then推論規則を、入力文書特徴取得部218dで取得された入力文書の特徴と照合することで、入力文書中の単語、句、文を重要度順にランキングする規則による要約部218fとを有している。

【0062】また、要約部218は、特定の単語や句、その他のパターンの存在、その順番、互いの近さ等と要約における有用性との相関関係についての統計データベース218gからの統計情報と入力文書の特徴とを比較50 し、その結果を用いて入力文書中の単語、句、文の重要

度順のランキングを調整する統計情報による要約部21 8hと、ユーザからの要約率や要約結果の長さの情報 と、要約部218hで調整された入力文書中の単語、 句、文の重要度順のランキングを基に、要約文を作成す る要約文作成部218iとを有している。

【0063】図15のフローチャートを使用して、規則と統計情報による要約部218の動作を説明する。ステップST81で、ユーザからの要約率または要約結果の長さの指定情報を取得する。この場合、ユーザ仕様抽出部218bは、記憶装置300の記憶バッファ306よりユーザからの要約率または要約結果の長さの指定情報を抽出し、この指定情報を要約制御部218aに供給する。

【0064】次に、ステップST82で、記憶装置300の記憶バッファ301に記憶されている入力文書の言語を判定する。この場合、記憶装置300の記憶バッファ302に記憶されている上述した言語判定部213による言語判定結果を利用できる。そして、ステップST83で、この言語判定結果に基づき、文章分割部218cによって、入力文書を単語、句、文等に分割し、その分割済入力文書を記憶装置300の記憶バッファ309に記憶する。

【0065】次に、ステップST84で、入力文書特徴取得部218dによって、記憶バッファ309に記憶されている分割済入力文書より、単語や句の現れる頻度や互いの近さ等の特徴を取得する。そして、ステップST85で、要約部218fによって、特定の単語や句、その他のパターンの存在、その順番、互いの近さ等が要約における有効性にどんな影響があるかについてのif-then推論規則を、入力文書の特徴と照合し、入力文書中の単語、句、文を重要度順にランキングする。

【0066】次に、ステップST86で、要約部218 hによって、特定の単語や句、その他のパターンの存 在、その順番、互いの近さ等と要約における有用性との 相関関係についての統計情報と、入力文書の特徴とを比 較し、その結果を用いて入力文書中の単語、句、文の重 要度順のランキングを調整する。そして、ステップST 87で、要約文作成部218iによって、ユーザからの 要約率や要約結果の長さの情報と、要約部218hで調整された入力文書中の単語、句、文の重要度順のランキングを基に、ユーザからの要約率や要約結果の長さに適 合するように要約文を作成する。そして、ステップST 88によって、作成された要約文を要約結果として、記憶装置300の記憶バッファ304に記憶する。

【0067】図16は、翻訳部216の構成を示している。この翻訳部216は、全体の動作を制御する翻訳制御部216aと、記憶装置300の記憶バッファ306より、翻訳仕様を抽出して翻訳制御部216aに供給するユーザ仕様抽出部216bと、記憶装置300の記憶バッファ304に要約結果として記憶されているテンプ

レートを他の自然言語に翻訳するテンプレート翻訳部221と、記憶装置300の記憶バッファ301に記憶されている入力文書または記憶バッファ304に要約結果として記憶されている入力文書の要約を他の自然言語に翻訳するテンプレート以外の翻訳部222とを有している。

16

【0068】図17のフローチャートを使用して、翻訳部216の動作を説明する。ステップST91で、ユーザからの翻訳仕様を取得する。この場合、ユーザ仕様抽出部216bは、記憶装置300の記憶バッファ306より翻訳仕様を抽出し、この翻訳仕様を翻訳制御部216aに供給する。そして、ステップST92で、翻訳仕様がテンプレートの翻訳を指定しているか否かを判定する

【0069】テンプレートの翻訳を指定しているときは、ステップST93で、翻訳部221によって、記憶バッファ304に記憶されている要約結果としてのテンプレートの翻訳を行って、その翻訳結果を記憶装置300記憶バッファ305に記憶する。一方、テンプレートの翻訳ではなく、入力文書の全体またはその入力文書の要約の翻訳を指定しているときは、ステップST94で、翻訳部222によって、記憶装置300の記憶バッファ301に記憶されている入力文書の要約の翻訳を行って、その翻訳結果を記憶バッファ305に記憶する。

【0070】図18のフローチャートを使用して、テンプレート翻訳部221の動作をさらに詳しく説明する。ステップST101で、記憶バッファ304よりテンプ30 レートとそれに付随する全ての情報(各スロットの埋められた情報)を抽出する。そして、ステップST102で、テンプレート出力言語を取得する。この出力言語の情報は、翻訳仕様に含まれており、翻訳制御部216aより供給される。

【0071】次に、ステップST103で、テンプレート中のスロットを順番に翻訳していくためのカウント値iを1に初期化する。そして、ステップST104で、カウント値iがスロット数より大きく、全てのスロットのとの翻訳が終わったか否かを判定し、全てのスロットの翻訳が終わったときは翻訳動作を終了する。一方、全てのスロットの翻訳が終わっていないときは、ステップST105で、スロットiの翻訳方法を取得し、ステップST107で、その翻訳方法をスロットiの内容に適用して翻訳を実行する。

【0072】そして、ステップST108で、出力言語でのスロット表示規則を実行し、ステップST109で、その結果を記憶装置300の記憶バッファ305に翻訳結果として記憶する。そして、ステップST110で、カウント値iをインクリメントして、ステップST104に戻り、次のスロットの翻訳処理に移行する。

50

部223dと、この構文解析部223dで構文解析済みの入力文を、部分毎に対訳例文データベース223eからの対訳ペアと照合して翻訳語句を得る推論による翻訳実行部223fからの入力文の各部分の翻訳語句を組み合わせて翻訳文を作成する翻訳文作成部223gとを有している。対訳例文データベース223eには、構文解析済の入力言語(原言語)

表現とそれに対応する出力言語(目標言語)表現のペア

が数多く保存されている。

18

【0073】図19のフローチャートを使用して、テンプレート以外の翻訳部222の動作をさらに詳しく説明する。まず、ステップST111で、翻訳対象である入力文書または要約の分野を判定する。この場合、記憶を置300の記憶バッファ303に記憶されている上述した分野判定部214による分野判定結果を利用できる。そして、ステップST112で、翻訳対象である入文書または要約の言語を判定する。この場合、記憶装したうの記憶バッファ302に記憶されている上述した言語判定部213による言語判定結果を利用できる。さらに、ステップST113で、出力言語を取得する。この出力言語の情報は、翻訳仕様に含まれており、翻訳制御部216aより供給される。

0 【0078】図21のフローチャートを使用して、翻訳 実行部223の動作を説明する。まず、ステップST1 21で、文章分割部223bによって、翻訳対象として の入力文を単語、句、文等に分割し、その分割済み入力 文を記憶装置300の記憶バッファ310に記憶する。 そして、ステップST122で、形態素解析部223c によって、分割された入力文の単語や句に形態素解析を 行って、その解析結果を構文解析部223dに供給す

【0074】次に、翻訳対象としての入力文書またはその要約に対する翻訳を実行する。上述せずも、この翻訳部 222は、入力言語L I_1 ~L I_n のそれぞれから出力言語L O_1 ~L O_m のいずれかへの翻訳を可能とする。そこで、ステップST114-1、ステップST114-2・・・・、ST114-kで、それぞれ[入力言語L I_1 、出力言語L O_1]、[入力言語L I_1 、出力言語L O_1]、[入力言語L I_1 、出力言語L O_1] の組み合わせであるか否かを判定する。そして、それぞれの組み合わせであるときは、ステップST115-1、ST115-2、・・・、ST115-kで、翻訳実行部によって、その組み合わせに対応する翻訳を実行し、ステップST116で、記憶装置300の記憶バッファ305に、その翻訳結果を記憶する。

【0079】次に、ステップST123で、構文解析部 20 223 dによって、形態素解析の解析結果から連続した 単語や句の集合に構文解析をする。そして、ステップS T124で、翻訳実行部223 fによって、構文解析済 みの入力文を部分毎に対訳例文データベース223 eの中の対訳ペアと照合し、さらにステップST125で、 最も近い対訳ペアを選択し、その目標言語部分を翻訳語 句として得る。そして、ステップST126で、入力文の全ての部分の照合が終了したか否かを判定し、終了するまでステップST124、ST125の処理を繰り返し実行する。

【0075】一方、いずれの組み合わせによる翻訳でもないときは、ステップST117で、翻訳部222は翻訳制御部216aにエラー情報を送る。これにより、中央制御部217よりユーザインタフェース部201にエラー情報が供給され、エラーメッセージ部206でエラーメッセージが生成され、例えば出入カインタフェース部100のモニタ106にエラーメッセージが表示される。

30 【0080】入力文の全ての部分の照合が終了したときは、ステップST127で、翻訳文作成部223gによって、入力文の各部分の翻訳語句を組み合わせて翻訳文を作成し、ステップST128で、その作成された翻訳文を翻訳結果として記憶装置300の記憶バッファ305に記憶する。

【0076】図20は、テンプレート以外の翻訳部222における翻訳実行部223の構成を示している。この翻訳実行部223は、全体の動作を制御する翻訳実行制御部223aと、翻訳対象としての記憶バッファ301に記憶されている入力文書または記憶バッファ304に記憶されている入力文書の要約(以下、「入力文」という)を単語、句、文等に分割する文章分割部223bとを有している。翻訳実行制御部223aの動作は、テンプレート以外の翻訳部222を構成する翻訳制御部222aによって制御されている。

【0081】図22は、音声認識部202の構成を示している。音声認識部202は、全体の動作を制御する音声認識制御部202aと、ローカルまたはリモートの場所のユーザから出力入力コントロール部205を介して音声波を取得する音声波取得部202bと、記憶装置300の記憶バッファ306より、ユーザからの言語仕様を抽出して音声認識制御部202aに供給するユーザ仕様抽出部216cと、音声波取得部202bで取得された音声波より単語、句、文等を認識する言語1~言語 n用のn個の音声認識部202d₁~202d_nとを有している。

【0077】また、翻訳実行部223は、文章分割部223bで分割された入力文の単語や句に後述する構文解析の前処理としての形態素解析をする形態素解析部223cの解析結果に基づいて、連続した単語や句の集合に構文解析をする構文解析

【0082】図23のフローチャートを使用して、音声 認識部202の動作を説明する。まず、ステップST1 31で、音声波取得部202bによって、ローカルまた はリモートの場所のユーザから電話やマイクロフォンを

50

通じて音声波を取得し、ステップST132で、その音 声波を記憶装置300の記憶バッファ311に記憶す る。そして、ステップST133で、ユーザ仕様抽出部 202cによって、音声波の自然言語を示すユーザから の言語仕様を取得する。この場合、ユーザ仕様抽出部2 02cは、記憶装置300の記憶バッファ306より言 語仕様を抽出し、この言語仕様を音声認識制御部202 aに供給する。

【0083】次に、ステップST $134_{-1}\sim 134_{-n}$ で、それぞれ言語仕様で示される自然言語が言語 $1\sim$ 言語 nであるか否かを判定する。そして、言語 $1\sim$ 言語 nであるときは、それぞれステップST $135_{-1}\sim 135_{-n}$ で、音声認識部 $202d_1\sim 202d_n$ によって、記憶バッファ311に記憶された音声波に対する言語 $1\sim$ 言語 nの音声認識を実行する。そして、ステップST136で、音声波から認識された単語、句、文等を音声認識結果として記憶装置300の記憶バッファ312に記憶する。

【0084】一方、言語仕様で示される自然言語が言語 1~言語 n のいずれでもないときは、ステップ S T 1 3 7で、音声認識制御部 2 0 2 a はユーザインタフェース部 2 0 1 にエラー情報を送る。これにより、エラーメッセージ部 2 0 6 でエラーメッセージが生成され、例えば出入力インタフェース部 1 0 0 のモニタ 1 0 6 にエラーメッセージが表示される。

【0085】図24は、自然言語理解部203の構成を示している。この自然言語理解部203 a と、ローカルまたはリモートの場所のユーザから出入力コントロール部205を介して自然言語表現を取得し、または上述と記憶バッファ312に記憶されている音声認識結果を自然言語表現として取得する自然言語表現取得部203b と、この自然言語取得部203bで取得した自然言語表現の言語を判定し、その判定結果を自然言語理解制御部203aに供給する言語判定部203cと、自然言語表現(ユーザ自然言語コマンド)を解析し、ユーザ仕様としてのシステムコマンド表現に変換する言語1~言語 n 間の n 個の自然言語解析部202d 1~202d n とを有している。

【0086】言語判定部203cは、上述した言語判定部213と同様に構成され、ユーザからの言語仕様があるときは、その言語仕様を記憶装置300の記憶バッファ306より抽出して言語判定結果とすると共に、ユーザからの言語仕様がないときは、規則や統計情報による言語判定処理によって言語判定結果を得るように構成されている。

【0087】図25のフローチャートを使用して、自然 言語理解部203の動作を説明する。まず、ステップS T141で、自然言語表現取得部203bによって、ロ ーカルまたはリモートの場所のユーザより出入力コント ロール部205を介して自然言語表現を取得し、あるいは記憶バッファ312より音声認識結果としての自然言語表現を取得し、記憶装置300の記憶バッファ313にユーザ自然言語コマンドとして記憶する。そして、ステップST142で、言語判定部203cによって、取

20

テップST142で、言語判定部203cによって、取得した自然言語表現の言語を判定し、この言語判定結果を自然言語理解制御部203aに供給する。

【0088】次に、ステップST143- $_1$ ~143 $_{-n}$ で、それぞれ言語判定結果で示される自然言語が言語1~言語 $_1$ ~言語 $_1$ であるか否かを判定する。そして、言語1~言語 $_1$ であるときは、それぞれステップST144- $_1$ ~144- $_n$ で、自然言語解析部203 $_1$ ~203 $_1$ $_n$ によって、記憶バッファ313に記憶された自然言語表現に対する言語1~言語 $_1$ 0自然言語解析を実行する。そして、ステップST145で、言語解析結果としてのシステムコマンド表現を記憶装置300の記憶バッファ306にユーザからの仕様として記憶する。

【0089】一方、言語判定結果で示される自然言語が言語1~言語nのいずれでもないときは、ステップST146で、自然言語理解制御部203aはユーザインタフェース部201にエラー情報を送る。これにより、エラーメッセージ部206でエラーメッセージが生成され、例えば出入力インタフェース部100のモニタ106にエラーメッセージが表示される。

【0090】図26は、自然言語理解部203における自然言語解析実行部224の構成を示している。この解析実行部224は、全体の動作を制御する自然言語解析実行制御部224aと、記憶バッファ313に記憶されている自然言語表現を単語、句、文等に分割する文章分割部224bとを有している。解析実行制御部224aの動作は、自然言語理解制御部203aによって制御されている。

【0091】また、解析実行部224は、文章分割部2 24 b で分割された、自然言語表現の単語や句に後述す る構文解析の前処理としての形態素解析をする形態素解 析部224cと、この形態素解析部224cの解析結果 に基づいて、連続した単語や句の集合に構文解析をする 構文解析部224dと、この構文解析部224dで構文 解析済みの自然言語表現を、部分毎に自然言語/システ 40 ムコマンド対訳例文データベース224eからの対訳ペ アと照合してコマンド言語意味表現を得る推論による翻 訳実行部224fと、この翻訳実行部224fからの自 然言語表現の各部分のコマンド言語意味表現を組み合わ せてシステムコマンド表現を作成するシステムコマンド 表現生成部224gとを有している。対訳例文データベ ース224eには、構文解析済の自然言語表現とそれに 対応するコマンド言語意味表現のペアが数多く保存され ている。

【0092】図27のフローチャートを使用して、解析 50 実行部224の動作を説明する。まず、ステップST1 51で、文章分割部224bによって、解析対象としての自然言語表現を単語、句、文等に分割し、その分割済み自然言語表現を記憶装置300の記憶パッファ314に記憶する。そして、ステップST152で、形態素解析部224cによって、分割された自然言語表現の単語や句に形態素解析を行って、その解析結果を構文解析部224dに供給する。

【0093】次に、ステップST153で、構文解析部224dによって、形態素解析の解析結果から連続した単語や句の集合に構文解析をする。そして、ステップST154で、翻訳実行部224fによって、構文解析済みの自然言語表現を部分毎に対訳例文データベース224eの中の対訳ペアと照合し、さらにステップST155で、最も近い対訳ペアを選択し、コマンド言語意味表現を得る。そして、ステップST156で、自然言語表現の全ての部分の照合が終了したか否かを判定し、終了するまでステップST154、ST155の処理を繰り返し実行する。

【0094】自然言語表現の全ての部分の照合が終了したときは、ステップST157で、システムコマンド表 20 現生成部224gによって、自然言語表現の各部分のコマンド言語意味表現を組み合わせてシステムコマンド表現を生成し、ステップST158で、その生成されたシステムコマンド表現をユーザ仕様として記憶装置300の記憶バッファ306に記憶する。

【0095】図28は、出力部212の構成を示している。この出力部212は、全体の動作を制御する出力制御部212aと、記憶装置300の記憶バッファ306より、出力仕様を抽出して出力制御部212aに供給するユーザ仕様抽出部212bと、記憶装置300の記憶バッファ302~305等に記憶されている要約結果、翻訳結果、言語判定結果、分野判定結果等の出力文書をページャに送信するためのページャ出力部212cと、出力文書を電話機に送信するための電話出力部212dとを有している。

【0096】また、出力部212は、出力文むを電子メイルに送信するための電子メイル出力部212eと、出力文むをSGML文むやHTML文むを保存表示できるローカルまたはリモートにある設備に送信するためのSGML/HTML出力部212fと、出力文むをローカルまたはリモートのファイルやデータベースに保存するためのファイル/データベース出力部212gと、出力文むをファクシミリに送信するためのファクシミリ出力部212hとを有している。

【0097】図29のフローチャートを使用して、出力部212の動作を説明する。ステップST161で、要約結果、翻訳結果、言語判定結果、分野判定結果等の出力文書の出力先を指定するユーザからの出力仕様を取得する。この場合、ユーザ仕様抽出部212bは、記憶装置300の記憶バッファ306より出力仕様を抽出し、

この出力仕様を出力制御部212aに供給する。そして、ステップST162で、出力仕様がページャを指定しているか否かを判定する。ページャを指定しているときは、ステップST163で、ページャ出力部212cによって、出力文書をページャに送信する。

22

【0098】ステップST162でページャを指定していないときは、ステップST164で、出力仕様が電話機を指定しているか否かを判定する。電話機を指定しているときは、電話出力部212dによって、出力文書を間に送信する。つまり、ステップST165で、出力文書(テキストデータ)を音声合成部204で音声信号に変換し、ステップST166で、この出力文書に対応した音声信号を電話回線を通じて電話機に送信する。【0099】ステップST164で電話機を指定していないときは、ステップST167で、出力仕様が電子メイルを指定しているか否かを判定する。電子メイルを指

ないときは、ステップST167で、出力仕様が電子メイルを指定しているか否かを判定する。電子メイルを指定しているときは、電子メイル出力部212eによって、ステップST168で、出力文書を電子メイルに送信する。

【0100】ステップST167で電子メイルを指定していないときは、ステップST169で、SGML文書やHTML文書を保存表示できるローカルまたはリモートの設備を指定しているか否かを判定する。その設備を指定しているときは、SGML/HTML出力部212fによって、出力文書をその設備に送信する。すなわち、ステップST170で、SGMLフォーマットやHTMLフォーマットのページを生成し、ステップST171で、そのページをローカルまたはリモートの設備に送信する。

0 【0101】ステップST169でSGML文書やHTML文書を保存表示できるローカルまたはリモートの設備を指定していないときは、ステップST172で、出力仕様がローカルまたはリモートのファイルやデータベースを指定しているか否かを判定する。そのファイルやデータベースを指定しているときは、ステップST173で、ファイル/データベース出力部212gによって、出力文書をローカルまたはリモートにあるファイルやデータベースに保存する。

【0102】ステップST172でファイルやデータベ 40 ースを指定していないときは、ステップST174で出 力仕様がファクシミリを指定しているか否かを判定す る。ファクシミリを指定しているときは、ファクシミリ 出力部212hによって、出力文書をファクシミリに送 信する。すなわち、ステップST175で、出力文書 (テキストデータ)をイメージデータに変換し、ステップST176で、そのイメージデータをファクシミリに 送信する。

【0103】ステップST174でファクシミリを指定していないときは、ステップST177で、出力制御部 50 212aは中央制御部217にエラー情報を送る。これ により、中央制御部217よりユーザインタフェース部201にエラー情報が供給され、エラーメッセージ部206でエラーメッセージが生成され、例えば出入力インタフェース部100のモニタ106にエラーメッセージが表示される。

【0104】図30は、上述した図1に示す多言語情報処理システム10が、コンピュータネットワーク上でアクセス可能なソフトウェアのシステムを構成している接続例を示している。この場合、多言語情報処理システム10はLAN(Local Area Network)122上に接続されたコンピュータ121上で作動している。LAN122は、さらにWAN(Wide Area Network)126、例えばインターネットの一部に接続されている。WAN126は、さらにLAN125やLAN127等にも接続されている。ユーザ124はLAN125に接続されているコンピュータ123から操作する。情報源129はLAN3に接続されているコンピュータ3に関連付けられている。

【0105】情報源129は、HTMLファイルを送信するワールドワイドウェブ(WWW)のサーバープログラムやその他のタイプのサーバープログラムのように、必要に応じて情報を送信する手段と見ることができる。また情報源129は、リモートのコンピュータで作動する電子メイル送信プログラムやファクシミリ送信機など独立して情報を送信する手段である場合もある。多言語情報処理システム10は、ユーザ124とは独立して入力文書を受け取りそれを記憶装置に保存する。その後に、ユーザが多言語情報処理システム10に接続し、保存済の入力文書を選択したとき、それを解析することとなる。

【0106】多言語情報処理システム10はオンラインでもオフラインでも操作可能である。オンラインモードでは、多言語情報処理システム10に接続したユーザがシステム10と交信し、入力文書、出力先、入力言語・分野、その他の情報を指定する。オンラインモードでは、ユーザは要約また翻訳の結果をすぐに表示させて見ることができる。オフラインモードでは、まずユーザがシステムに接続し、システム10がオンライン交信なしに情報の処理を行えるように、ユーザのプロファイルを作成する。その後、ユーザはシステム10との接続を絶ち、多言語情報処理システム10はユーザとの交信なしに独立して文書の処理を行う。

【0107】ユーザがシステムと交信する手段も多種類用意されている。固定または無線のコンピュータネットワークに接続するローカルまたはリモートのコンピュータ上のGUI(Graphical User Interface)を操作して交信するのも一つの例である。またコンピュータのテキスト画面でタイプしたり、メニューから単語を選ぶことにより自然言語コマンドを通してユーザが交信するのも可能な例である。

【0108】また、図1に示す多言語情報処理システム10によって、図31に示すように、ユーザが電話によってアクセスできるシステムを構成することも可能である。ユーザ130は、電話回線132に接続されている固定、モービルまたは無線の電話131を用いる。多言語情報処理システム10は、電話回線インタフェース133を備えているコンピュータ134上で作動してい

24

【0109】この場合、多言語情報処理システム10は、ユーザ130からの音声波を受け取り、記憶バッファに保存し、音声認識、自然言語理解を行い、得られたコマンドを実行する。ユーザ130に出力結果を送信するとき、多言語情報処理システム10は、出力結果を音声波に合成し、電話回線132を通じてユーザに送信する。

【0110】入力文書の言語や分野を指定する情報は様々な方法で入力文書自体に注釈として含めることができる。例えば、HTMLフォーマットの入力文書はSGMLのタグを使って次のように言語(LANGUAGE)や分野(SUBJECT)の情報を備えることができる。

[0111]

<LANGUAGE value="japanese">

<LANGUAGE value="english">

<SUBJECT value="internal medicine">

⟨SUBJECT value="unix programming⟩

また、既存のHTMLのMETAタグが、この情報を含むように拡張される。

<META name="language" content="japanese">

<META name="language" content="english">

<META name="subject" content="unix programming"> 入力文書を要約する際の規則を系統立てるテンプレート も様々な方法で実施することができる。図32に、テン プレートの一例を示している。このテンプレートは名前 部136、分野部137、情報源部138、スロット部 139から構成されている。名前部136にはテンプレ ートの名前が書かれている。分野部137には、そのテ ンプレートが適用され得る分野のリストと、その分野の 40 文書を要約する際の適切性を示すスコアとが書かれてい る。情報源部138には、このテンプレートを埋めるた めに必要な情報を入手する方法が書かれている。スロッ ト部139には、テンプレートのスロットが単数または 複数含まれている。それぞれのスロットには、スロット 名140、スロット値を得るための規則141、スロッ ト値を表示するための規則147、スロット値を翻訳す るための規則153、スロット値159が備えられてい

【0112】スロット値を得るための規則141は、言 50 語ごとに整理されている。スロット値を得るための規則

要約を柔軟に行わせることができる。例えば、外国語で むれた大量の電子メイルを毎日受け取るユーザは、それぞれの電子メイル文書を1文に要約し、母国語に翻訳 するように指定することができる。そのようにすること

26

によって、ユーザはすばやく全ての電子メイル文書をチェックし、詳しく読むことが必要な重要な文書を選び出すことができる。

【0118】また、多言語情報処理システム10は、コンピュータネットワークや電話回線などの様々な通信情10 報チャンネルで作動させることができるため、様々な情報源から入手する情報を管理することが可能となる。このシステム10は、さらに要約された、また翻訳された文書を様々なチャンネルに送信することもできる。

【0119】例えば、ユーザが携帯電話のみを携えた旅行中に外国語で書かれたファクシミリ文書を受け取った場合、既にファクシミリを受信し保存している多言語情報処理システム10に電話で接続し、そのファクシミリ文書の要約をユーザの母国語で提示するよう指示することができる。これに対して、多言語情報処理システム10は、ファクシミリ文書のイメージデータを認識し、要約し、翻訳し、合成音で電話先のユーザに提示することができる。

【0120】また、多言語情報処理システム10は、キーボード入力(タイプ入力)、音声入力、さらにその他の手段により入力された自然言語によるシステムへの指示を可能にしている。例えば、ユーザはコンピュータのキーボードでタイプすることにより、電話から話しかけることにより、電話から話しかけることにより、また携帯端末のタッチスクリーンのメニューから自然言語表現を組み立てることにより、多言語情報処理システム10へ指示を出すことができる。そのようにして、ユーザは様々な通信情報チャンネルを介して、簡潔で直感的な方法でシステムへの指示を出すことができる。

【0121】ここでシステムへの指示とは、多言語情報 処理システム10への入力文書の指定、要約また翻訳された出力文書の送信先の指定、入力文書の言語の指定、出力言語の指定、多言語情報処理システム10との交信に使用する言語、希望する要約率や要約結果の長さなど がある。さらに、ユーザは埋めたいテンプレートを指定するか、システム10が自動的にテンプレートを選択すべきかを指示したりできる。また、ユーザは自然言語で 多言語情報処理システムに質問をし、システム10はその質問にもっともふさわしいテンプレートを選択し、テンプレートを情報で埋め、その結果をユーザに提示することができる。

[0122]

【発明の効果】この発明によれば、入力文書を要約する機能、さらには入力文書やその要約を他の自然言語に翻 50 訳する機能を持つものであり、入力文書の言語が母国語

141の概には、少なくとも一つのデフォルト規則14 6が用意されており、入力言語に対応する規則が見つからない場合に適用される。スロット値を得るための規則 141の概には、さらに言語毎に対応する規則の概14 2、145が設けられている。言語毎の規則は、言語指定概143と規則概144からなり、規則概144は、入力文書からそのスロット値の情報を得るための仕様が記されている。入力文書から抽出されるべき単語、句や節などを特定したパターンマッチング表現(正規表現)などがその例である。

【0113】スロット値を表示するための規則147も 言語毎に整理されている。スロット値を表示するための 規則147の 概には、少なくとも一つのデフォルト規則 152が用意されており、入力言語に対応する規則が見つからない場合に適用される。スロット値を表示するための規則147の 概には、さらに言語毎に対応する規則の 概148,151が設けられている。言語毎の規則は スロット値を表示する仕様が記されている。スロット値を表示する仕様が記されている。スロット値を 含むプリントコマンドを含むプログラム文などがその例である。

【0114】スロット値を翻訳するための規則153も言語毎に整理されている。スロット値を翻訳するための規則153の概には、少なくとも一つのデフォルト規則158が用意されており、入力言語に対応する規則が見つからない場合に適用される。スロット値を翻訳するための規則153の概には、さらに言語毎に対応する規則の概154、157が設けられている。言語毎の規則は言語指定概155と規則概156からなり、規則概はスロット値を翻訳するための仕様が記されている。スロット値の属する分野の指定などがその例である。

【0115】スロット値159も言語毎に整理されている。スロット値159の概には、少なくとも一つのデフォルト値164が用意されており、入力言語に対応する規則が見つからない場合に適用される。スロット値159の概には、さらに言語毎に対応する値の概160.163が設けられている。言語毎のスロット値の概には言語指定概161とテキスト概162からなり、テキスト概には入力文掛から抽出したスロット値が記される。

【0116】以上説明したように、図1に示す多言語情報処理システム10は、ある自然言語から別の自然言語へと翻訳する翻訳部216を備えているため、入力文書が掛かれている言語をユーザが理解できない場合でも、入力文書中の情報をユーザが理解することが可能となる。

【0117】また、多言語情報処理システム10は、入力文書を要約する要約部215を備えているため、入力文書全体を読む時間がないユーザも文書中の情報を理解することが可能となる。そして、ユーザは要約率または要約結果の長さを指定できるので、自分の必要にあった

でない場合や入力文書が大量である場合でも、ユーザは 入力文書中の情報を容易に理解できる等の効果がある。

【図面の簡単な説明】

, 4.

【図1】実施の形態としての多言語情報処理システムの 構成を示すブロック図である。

【図2】多言語情報処理システムの動作概要を説明する ためのフローチャートである。

【図3】多言語情報処理システムの入力受領部の構成を 示すブロック図である。

【図4】入力受領部の動作を説明するためのフローチャ 10 構成を示すブロック図である。 ートである。

【図5】入力受領部のファクシミリ文書の受領動作を説 明するためのフローチャートである。

【図6】多言語情報処理システムの言語判定部の構成を 示すプロック図である。

【図7】言語判定部の動作を説明するためのフローチャ ートである。

【図8】多言語情報処理システムの分野判定部の構成を 示すブロック図である。

【図9】分野判定部の動作を説明するためのフローチャ 20 トである。 ートである。

【図10】多言語情報処理システムの要約部の構成を示 すブロック図である。

【図11】要約部の動作を説明するためのフローチャー トである。

【図12】要約部のなかのテンプレートによる要約部の 構成を示すブロック図である。

【図13】テンプレートによる要約部の動作を説明する ためのフローチャートである。

【図14】要約部のなかの規則と統計情報による要約部 30 の構成を示すブロック図である。

【図15】規則と統計情報による要約部の動作を説明す るためのフローチャートである。

【図16】多言語情報処理システムの翻訳部の構成を示 すブロック図である。

【図17】翻訳部の動作を説明するためのフローチャー トである。

【図18】翻訳部のなかのテンプレート翻訳部の動作を 説明するためのフローチャートである。

動作を説明するためのフローチャートである。

【図20】テンプレート以外の翻訳部における翻訳実行 部の構成を示すブロック図である。

28

【図21】翻訳実行部の動作を説明するためのフローチ ャートである。

【図22】多言語情報処理システムの音声認識部の構成 を示すブロック図である。

【図23】音声認識部の動作を説明するためのフローチ ャートである。

【図24】多言語情報処理システムの自然言語理解部の

【図25】自然言語理解部の動作を説明するためのフロ ーチャートである。

【図26】自然言語理解部における自然言語解析実行部 の構成を示すブロック図である。

【図27】自然言語解析実行部の動作を説明するための フローチャートである。

【図28】多言語情報処理システムの出力部の構成を示 すブロック図である。

【図29】出力部の動作を説明するためのフローチャー

【図30】多言語情報処理システムがコンピュータネッ トワーク上でアクセス可能なシステムを構成する接続例 を示した図である。

【図31】多言語情報処理システムがユーザによる電話 アクセスが可能なシステムを構成する接続例を示した図 である。


【図32】入力文書を要約する際に使用されるテンプレ ート例を示す図である。

【符号の説明】

10・・・多言語情報処理システム、100・・・出入 カインタフェース部、101・・・電話回線インタフェ ース、102・・・ネットワークインタフェース、10 3・・・キーボード、104・・・マイクロホン、10 5・・・マウス、タッチスクリーン等、106・・・モ ニタ、200···CPU、201···ユーザインタ フェース部、202・・・音声認識部、203・・・自 然言語理解部、204・・・音声合成部、205・・・ 出入力コントロール部、211・・・入力受領部、21 2・・・出力部、213・・・言語判定部、214・・ 【図19】翻訳部のなかのテンプレート以外の翻訳部の 40 ・分野判定部、215・・・要約部、216・・・翻訳 部、217・・・中央制御部、300・・・記憶装置


【図1】

実施の形態(多言語情報処理システム)




【図10】

要約部




【図2】

多言語情報処理システムの動作概要




【図3】

入力受領部




[図4]

入力受領部の動作




【図11】

要約部の動作




【図5】

ファクシミリ文書の受領動作




【図7】

言語判定部の動作




[図6]

言語判定部




[図8]

分野判定部



【図17】

翻訳部の動作




[図9]

分野判定部の動作

【図12】

テンプレートによる要約部




【図16】


【図18】

テンプレート翻訳部の動作

翻訳部


開始






【図13】

テンプレートによる要約部の動作




[図14]

規則と統計情報による要約部



【図31】 ユーザが電話によってアクセス可能なシステム




【図15】

規則と統計情報による要約部の動作

【図19】

テンプレート以外の翻訳部の動作





【図23】

音声認識部の動作

[図25]


自然言語理解部の動作






[図20]

翻訳実行部



【図21】

翻訳実行部の動作




[図22]

音声認識部


【図24】

自然言語理解部




【図26】

自然言語解析実行部



【図27】

自然言語解析実行部の動作



[図28] 【図29】 出力部 出力部の動作 開始 -217 中央制御部 ユーザから出力仕様を取得~~ST161 ST 162 **ST**183 start 300:配憶装置 end/error 212 YES 出力をページャに送信 ページャーに出力? -212a 21,2b ユーザ仕様 出力仕様 start HOT ST184 ST185 ユーザから 出力仕様 の仕様 抽出部 電話機 音声合成 に出力で ST166 21,2c ST167 音声出力を電話機に送信 <u>رخ</u> + يزد 306 start end 出力部 ST168 L 212d YES 出力を電子メイルに送信 start に出カ? 電話 出力 NO ST169 end 出力部 302~305 制御部 ST1170 21,2e SGNL/BTNL機器 に出力? >YES。SGML/HTMLフォーマットのページを生成 電子メイル start 要約結果・ end 出力部 翻訳結果・ SGML/HTML機器に出力を送信 21,2 f 出力 **首簡判定** ST172 文書 結果・分野 start SGML/HTML ST171 判定結果など end 出力部 ファイル/データペース に出力? YES 出力をファイルやデータベースに保存 <u>21,2</u>g ST,174 ST173 ファイル/デ*ータ ペ*-ス出力部 start NOI ST1,75 end 212h イメージデータに変換 に出力? ファクシミリ start 出力をファクシミリに送信 NO end 出力部 -ジの生成 ST176 エラーメッセー 出入力 コントロール部 出力文書

~205

供了

【図30】

コンピュータネットワーク上でのアクセス可能なシステム

[図32]

入力文 を要約する際に使用されるテンプレート例

